



AI för svetsning – med projektet Pictorial som exempel
Fogningsdagarna 2026

Pia Borg

Pia.borg@swerim.se

Project title: PICTORIAL – Predictive intelligent control for RSW

SWERIM

Start: Sept 2023 Time: 29 months Budget: 7.8 MSEK Funding: FFI Circularity

Goal:

An ML-model for process monitoring of RSW in large scale production by gathering, sorting, and labeling relevant data of all individual spot welds in a production line, that will predict weld quality, perceive trends and act on irregularities.

Objectives :

An intelligent quality monitoring system to advance circularity

- Predict and monitor weld quality in real-time
- Alert when quality starts to drift
- Enable corrective actions before defects occur
- Support sustainable material adoption in automotive production
- Enhance digitalization and cognitive support in manufacturing

Method:


- Use real production data from automotive factories
- Combine domain knowledge with machine learning (ML)
- Train and validate AI models in production-like environments
- Design user-friendly display for AI output

Integration of domain knowledge and data science

The result will be based on both welding knowledge and data science. Real production data will be used for training the model, something that is rare in the literature. Previously, simulated or experimental data have been used.

The difficulty for the mathematical model of RSW

The RSW process involves interactions between electromagnetic, thermal, mechanical, and metallurgical phenomena to make the optimal weld nugget. At the same time, the huge amount of data created is either single features or time series, making it mathematically complex. The data must be reliable when collected and stored.



Project leader:



SVETSRÅDET AB



Fordonsstrategisk
Forskning och
Innovation



The project is supported from:

Maskininlärning inom svetsning

Introduktion

- Svetsning är avgörande i fordonsindustrin – från kaross (RSW) till batteriproduktion (laser). Även annan svetsning har hög processvariator
- Ökad automatisering och komplexa processer driver behovet av smarta, datadrivna system.
- Maskininlärning (ML) används idag för att förbättra övervakning, beslutsfattande och processoptimering.

Varför?

- Traditionell kvalitetskontroll är reaktiv, tidskrävande och ofta förstörande.
- Sensorer genererar stora datamängder – ML kan identifiera mönster som människor inte ser.
- Målet: Färre defekter, bättre processförståelse, stabilare produktion.

Vad AI egentligen gör

1. Mönsterigenkänning –
Kamera ser rågform; DR-kurvor,
keyhole-dynamik
2. Prediktion –
Linsstorlek, penetration,
3. Optimering –
AI rekommenderar eller styr
parametrar i realtid

Relationship Between AI, ML, and DL



AI is the umbrella term for all technologies that enable machines to think and act like humans

AI includes Machine Learning (ML) and Deep Learning (DL)



ML is a subset of AI that enables machines to learn from data and improve over time

ML algorithms can be used to make predictions and decisions



DL is a subset of ML that uses neural networks to learn from data

DL algorithms can be used to identify patterns in data

- Narrow AI
 - e.g., Amazon's Alexa

- General AI
 - *Futuristic*
- Super AI
 - *Futuristic*

- Supervised learning
 - e.g., Google's Gmail spam filter

- Unsupervised learning
 - e.g., Facebook's friend suggestion feature

- Semi-supervised learning
 - Google Photos (uses both labeled and unlabeled data for image recognition)

- Reinforcement learning
 - Tesla's Autopilot system

- Feedforward Neural Networks (FNN)
 - e.g., Netflix's Recommendation System

- Convolutional Neural Networks (CNN)
 - e.g., Facebook's DeepFace (used for tagging suggestions in photos)

- Recurrent Neural Networks (RNN)
 - e.g., Apple's Siri (used for voice recognition and natural language understanding)

- Transformers
 - e.g., OpenAI's GPT-3 (used for generating human-like text)




Source: AISeCHub
Copyright © 2023. All rights reserved.

Sensorer är grunden

- RSW: dynamisk resistans, elektroddisplacement, kraft
- Laser: photodioder (thermal, plasma, reflected), IR-kameror, high-speed kamera, OCT
- GMAW/GTAW/SAW: vision, laserprofil, ström-spänning


Trend: sensorfusion för robust processövervakning

HSI



Industrial photogrammetry

Laser profilometry



Maskininlärningsmetoder

1. Supervised Learning


- Används när märkta data finns.
- Exempel:
 - Klassificering av defekter
 - Prediktion av linsstorlek, draghållfasthet
- Tekniker: SVM, Random Forest, Neurala nätverk.

2. Unsupervised Learning

- För stora mängder omärkta data (vanligt i produktion).
- Används för:
 - Klustring av normala/avvikande svetsar
 - Funktionsreducering (PCA, autoencoders)
 - Representation learning

3. Generaliserbar ML

- För att ML ska fungera i verklig produktion krävs modeller som klarar varierande förutsättningar.
- **Transfer Learning** – flytta modeller mellan robotar eller material.
- **Incremental Learning** – modellen uppdateras när ny data kommer.
- **Federated Learning** – flera produktionslinjer tränar modeller utan att dela rådata.



Märkt data = etikett =
rådata + korrekt svar (klass eller värde).

Maskininlärningsmetoder


Konventionell ML

- Traditionella maskininlärningsmetoder som använder matematiska modeller för att hitta samband mellan indata (t.ex. svetsparametrar) och utdata (t.ex. svetskvalitet). Kräver ofta att man manuellt väljer relevanta egenskaper eller variabler (features).
- **Exempel:**
Analysera sensordata (ström, spänning, elektrodtryck) från motståndspunktsvetsning (RSW) för att förutsäga om en svets är godkänd eller riskerar sprut.
Praktisk nytta: Enkel modell som kan ge snabb kvalitetsklassificering baserat på processparametrar.

Djupinlärning (t.ex. CNN, RNN)

En avancerad form av ML som använder neurala nätverk med många lager.

- **CNN (Convolutional Neural Network):** Bra för bildanalys, t.ex. identifiera defekter i svetsbilder.
- **RNN (Recurrent Neural Network):** Bra för tidsseriedata, t.ex. sensordata under svetsning.
- **Exempel:**
- **CNN:** Identifiera sprickor eller porositet i svetsar genom att analysera bilder från kamera eller termografi.
- **RNN:** Förutsäga svetskvalitet i realtid genom att analysera tidsserier av dynamisk resistans under svetscykeln.
Praktisk nytta: Automatiserad defektdetektering utan manuell feature-extraktion.



Klustering

- En metod för att gruppera data i kluster baserat på likheter, utan att veta i förväg vilka grupper som finns. Används för att upptäcka mönster eller avvikelser (anomalier) i svetsprocesser.
- **Exempel:**
Gruppera svetsar baserat på sensordata för att upptäcka avvikande beteenden, t.ex. felaktig elektrodposition eller materialstackning.
Praktisk nytta: Identifierar nya feltyper utan att behöva fördefinierade etiketter.

Dimensionsreduktion

- Teknik för att minska antalet variabler i en dataset, men behålla den viktigaste informationen. Gör analysen enklare och snabbare, t.ex. genom att komprimera sensordata.
- **Exempel:**
Komprimera hundratals sensordatafunktioner (strömkurvor, kraft, spänning) till några få nyckelvariabler som bäst beskriver svetsprocessen.
Praktisk nytta: Gör analys och visualisering enklare och snabbare.

Representation Learning

- Modeller som automatiskt lär sig att skapa kompakta och meningsfulla representationer av data, vilket gör det lättare att använda för olika ML-uppgifter.
- **Exempel:**
Låt modellen själv lära sig en kompakt representation av svetsprocessens signaler, som sedan används för kvalitetsprognos eller defektdetektering.
Praktisk nytta: Mindre behov av manuell feature-engineering.

Kontrastiv inlärning

- En metod som lär sig genom att jämföra likheter och skillnader mellan datapunkter. Hjälper modellen att bli robust även när data är omärkt (utan etiketter).
- **Exempel:**
Träna en modell att förstå skillnaden mellan "bra" och "dåliga" svetsar genom att jämföra par av sensordata från olika svetscykler.
Praktisk nytta: Förbättrar robusthet även när märkta data är begränsade.

Generaliserbar ML

Transfer Learning


- Återanvändning av en modell som redan är tränad på ett liknande problem, för att snabbt anpassa den till en ny uppgift. Sparar tid och data.
- **Exempel:**
Återanvänd en modell tränad på RSW för att snabbt anpassa den till laser-svetsning, där båda processerna har liknande signalmönster.
Praktisk nytta: Sparar tid och data vid införande av nya svetsmetoder.

Inkrementell inlärning

- Modellen uppdateras stegvis när ny data kommer, utan att börja om från noll. Viktigt när processer förändras över tid, t.ex. nya material eller svetsparametrar.
- **Exempel:**
Uppdatera modellen när nya material (t.ex. höghållfast stål eller aluminium) introduceras, utan att behöva träna om från början.
Praktisk nytta: Anpassar sig till förändringar i produktionen.

Federerad inlärning

- Träning av en gemensam modell över flera maskiner eller fabriker utan att dela rådata. Endast modelluppdateringar delas, vilket skyddar datasekretess.
- **Exempel:**
Bygg en gemensam ML-modell för svetskvalitet baserat på data från flera fabriker, utan att dela rådata (endast modelluppdateringar delas).
Praktisk nytta: Möjliggör samarbete mellan fabriker och skyddar datasekretess.



Processer och datainsamling

MIG/MAG-svetsning (smältsvetsning)

- Processen påverkas av bågglängd, droppöverföring, trådmätning, gas och pistolgeometri.
- Kvaliteten styrs av svetspoolens stabilitet, värmeförlust och fogtoleranser.
- Vanliga defekter: porositet, bristfällig inträngning, bindfel och sprut.



Datainsamling– MIG/MAG

Datotyp	Exempel
Elektriska	Ström, spänning, bågimpedans, transienttoppar
Ljud	Frekvensspektrum => stabilitet, kortslutningsfrekvens
Optiskt	Höghastighetsvideo, IR
Mekaniskt	Trådmatarhastighet, vibrationer
Geometri	Fogförskjutning, svetspoolens form
Efterkontroll	Penetration, porositet, svetsbredd, inträngning

Kombinerade sensorer ger bättre processförståelse – särskilt för dynamiska processer som GMAW.

Processer och datainsamling





Centrala processer i fordonsindustrin

- **Resistance Spot Welding (RSW)**
- 4000–6000 punktsvetsar per bil.
- Kvaliteten påverkas av: materialstack, elektrodslitage, strömkurvor, passningsgap.
- Vanliga defekter: för liten nugget, sprut, shunting.
- **Lasersvetsning**
- Avgörande för EV-batterier.
- Kräver precision, låg värmepåverkan och kontroll av keyhole-stabilitet.
- Defekter: porositet, sprut, lack of fusion, blowout.

Sensorer och datainsamling

- **RSW-sensorer**
- Dynamisk resistans (DR)
- Elektrodskraft
- Elektroddisplacement
- Vibration
- **Lasersvetsning**
- Fotodioder (termiskt, plasma, reflektion)
- IR-kameror
- Höghastighetskameror
- OCT för interna defekter

Kombinerade sensorer ger bättre processförståelse.




Stora nya trenden: Generaliserbar AI

Forskningen visar att modeller fungerar i labb men ofta fallerar i production.

Lösningar som nu utvecklas:

- Transfer Learning – använda modeller mellan maskiner
- Incremental Learning – kontinuerlig uppdatering utan retraining
- Federated Learning – fabriker tränar gemensamt utan datadelning



Vad ni som svetsansvariga och produktionsingenjörer behöver kunna

- AI kräver bra sensorer och stabil datainsamling
- Tänk: "Vilken signal säger mest om kvaliteten?"
- AI behöver era domänkunskaper (fit-up, geometri, process, material, kvalitet)
- Lär er diskutera med data scientists:
 - – vilket problem ska lösas?
 - – vilka sensorer finns?
 - – hur varierar processen?
- Modeller måste underhållas – inga engångsmodeller



Utmaningar & Framtid

Utmaningar

- Skillnader mellan labbdata och produktionsdata.
- Obalanserade datamängder (få defekter i verkligheten).
- Begränsad tolkbarhet hos djupa nätverk.
- Heterogenitet mellan maskiner och material.

Framtid och möjligheter

- Mer robusta ML-modeller som integrerar fysik + data.
- Virtuella sensorer som ersätter kostsam hårdvara.
- Realtidsstyrning baserat på förstärkt lärande.
- Möjlighet att drastiskt minska skräp- och kassationsnivåer.



Avslutning

AI är ännu ett verktyg i svetsarens verktygslåda – snabbt, uppmärksamt och lärande.

Det hjälper oss att:

- förutsäga istället för att reagera
- stabilisera processer
- minska energi och kassation
- höja produktiviteten

- Svetsprocesser genererar komplexa, dynamiska signaler.
- ML ger verktyg för kvalitetsförbättring, snabbare beslut och ökad automatisering.
- Den största potentialen ligger i generaliserbara, robusta modeller för verklig produktion.

